

# WEEKLY REPORT

张建伟

October 21, 2018

## 1 上周工作

### 1.1 博士论文进度

- 第一章绪论 (100%)
- 第六章结论 (100%)
- 初稿已经发给郝老师.

### 1.2 科研工作

- 三支的三期数据不求差直接输入网络, 得到的肝脏和肿瘤的 Dice 系数为 0.918 和 0.523, 相比于求差后的 0.908 和 0.471 有明显的提升, 说明求差后图像信息损失的更多.
- 经过粗略的观察后发现由于三期数据配准不精确导致求差后肝脏边缘出现了很多”窄带”, 这些窄带既影响了网络准确识别肝脏边界, 也严重影响着在肝脏边缘的肿瘤的分割.
- 上周和蔡老师讨论和我思考后针对配准较差的问题目前想了两个办法:
  1. 对三期数据重新筛选, 从每个病例中仅选出连续数片均配准较好的部分进行训练.
  2. 采用我之前的一个想法, 对三期数据的肝脏进行分割级别的标注, 然后训练 CNN 分割出三期的肝脏; 再寻找一个变形 (或配准) 的方法把三期的肝脏进行对齐 (或配准), 最后再进行肿瘤分割.

### 1.3 遇到的困难

- 第一个想法: 筛选三期数据会使数据量更少 (目前已有可用的数据量本来就不多)
- 第二个想法: 需要额外花时间标注另外两期的肝脏, 且需要寻找一个能够对肝脏做变形的算法, 且算法效果要比较好.

## 2 下周工作

- 初步试一下筛选数据
- 再找一些做变形 + 配准的论文, 要保证在肝脏变形后能通过向量场对整幅图像完整变形才能用于后续的肿瘤分割.

## 3 论文阅读

### 3.1 SVF-Net Learning deformable image registration using shape matching — MICCAI 2017

本文针对心脏配准, 提出了一套新的配准方法. 首先本文假设心脏已经被分割出来, 即已经有了心脏曲面; 然后使用一种不需要关联点的曲面匹配算法<sup>1</sup>对目标曲面变形, 再使用一个基于物理模型的 3D 样条方法<sup>2</sup>完成其余点的插值. 但由于这个基于物理模型的样条方法不能保证结果的光滑性, 因此本文提出使用 Stationary Velocity Field(SVF) 在配准时实现变换的可逆性和光滑性, 其中 SVF 的参数由一个 U-Net 训练得到.

### 3.2 An Unsupervised Learning Model for Deformable Medical Image Registration — CVPR 2018

本文提出了一种无监督的医学图像配准算法. 首先本文假设目标图像和待配准图像已经经过仿射变换, 处于图像中相同的位置和角度; 剩下的仅需要一个非仿射变换完成形变配准. 因此本文提出了类似于 U-Net 的两种网络

---

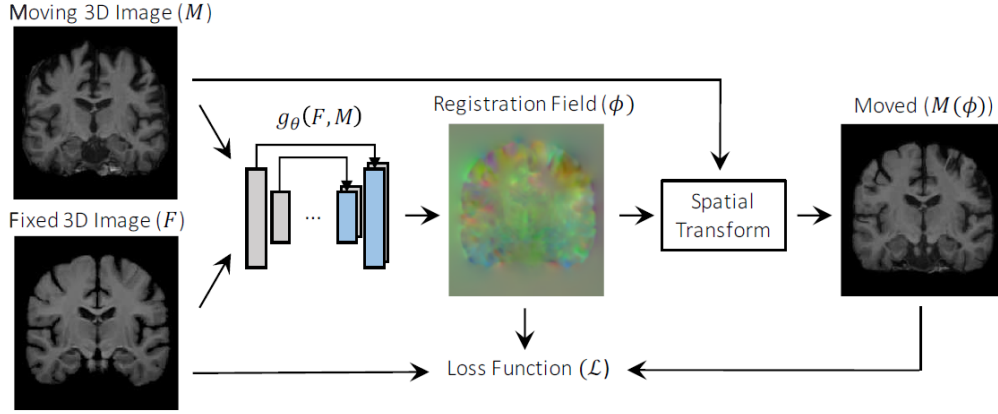
<sup>1</sup>Durrleman S, Prastawa M, Charon N, et al. Morphometry of anatomical shape complexes with dense deformations and sparse parameters[J]. NeuroImage, 2014, 101: 35-49.

<sup>2</sup>Davis, M.H., Khotanzad, A., Flamig, D.P., Harms, S.E.: A physics-based coordinate transformation for 3-D image matching. IEEE Med. Imaging 16, 317-328 (1997)

结构用于预测这个形变的变换场. 网络输入的是 3D 两通道的图像, 目标图像和待配准图像各占一个通道. 损失函数由 cross-correlation 和光滑性两项组成, 如下:

$$\mathcal{L}(F, M, \phi) = -CC(F, M(\phi)) + \lambda \sum_{p \in \Omega} \|\nabla \phi(p)\|^2. \quad (1)$$

其中第一项用于训练网络输出正确的变换场, 第二项用于保证输出结果的光滑性. 流程如下图所示.



### 3.3 Unsupervised Learning for Fast Probabilistic Diffeomorphic Registration — MICCAI 2018

本文继承于上一篇文章的工作, 引入了一个概率生成模型和一种新的学习方法. 概率生成模型中参数化变换函数的潜变量假设为多变量正态分布, 并且在本文中假设  $\mathbf{z}$  是一个稳定速度场 (stationary velocity field, SVF), 它通过常微分方程

$$\frac{\partial \phi^{(t)}}{\partial t} = v(\phi^{(t)})$$

定义了一个微分同胚映射. 而由于  $\mathbf{z}$  的后验概率  $p(\mathbf{z}|\mathbf{x}; \mathbf{y})$  难以计算, 所以使用变分方法得到近似的后验概率  $q_\psi(\mathbf{z}|\mathbf{x}; \mathbf{y})$ , 并用正态分布对该近似后验概率建模, 正态分布的均值和方差由神经网络来估计. 然后由该分布利用”重参数化技巧”采样得到  $\mathbf{z}_k$ , 然后本文提出使用一个七个 squaring and scaling 层计算  $\phi_{z_k} = \exp(\mathbf{z}_k)$ . (更多细节暂时看不懂了.....), 网络结构和上一篇文章类似, 增加了 SVF 和 square and scaling 结构.

